November 2022

基于LSTM特征提取与机器学习的趋势交易策略的信号过滤方法

Trade Filtering Method for Trend Following Strategy based on LSTM-extracted Feature and Machine Learning

梁俊[a,b], 黄可怡[c], 邱少健[a,1], 林海[a]， 连坑[c]

[a]华南农业大学数学与信息学院，广东省广州市 *510640*

[b]广州芯研信息科技有限公司，广东省广州市 *510000*

[c]诺维艾创（广州）科技有限公司，广东省广州市 *510800*

摘要. 趋势跟踪交易已经在量化金融领域中得到了广泛应用。它能抓住市场的重要单边趋势从而获得收益，但在震荡行情中仍存在连续亏损的问题。为进一步提高策略的绩效，通过参考止盈止损机制对期货价格制作涨跌标签，以 K 线数据、技术指标和时间序列特征构建特征组并使用长短期记忆神经网络进行特征提取，使用 6 种不同的机器学习分类器构建交易方向过滤器；使用螺纹钢连续合约数据作为样本，把分类器预测的涨跌方向作为过滤条件叠加到趋势跟踪策略的开仓条件之中，对交易信号进行筛选。实证发现，构建的过滤器均对策略绩效有提高作用，其中由 XGBoost 分类器构建的过滤器使策略的年化收益率由 6.39%提高到 15.68%；此外，通过黄金期货与豆粕期货的实验证明了基于机器学习模型预测的涨跌趋势作为交易方向过滤器，可提高趋势跟踪策略的绩效。

关键词: 机器学习；长短期记忆网络；时间序列预测；趋势交易；深度学习

Abstract. Trend following strategies have a wide-ranging role in quantitative trading fields, which can capture important unilateral market trends for large gains, while this is vulnerable to losses in the period of consolidation. In this paper, we explored the trend trading system in the Chinese futures market based on machine learning techniques and statistical methods. This research utilized the Long-Short-Term Memory network to extract features of time series then predicted the price movements by Machine Learning classifiers. Moreover, based on rebar futures data, the results reveal that the annualized return improved from 6.39% to 15.68% after the trading signals generated in the trading strategy were filtered using the XGBoost model. Also, futures on gold and soybean were used to further test the integrated strategy and the results of the experiment show the effectiveness of the model in filtering false trading signals.

Keywords. Machine Learning, LSTM, Time Series Forecasting, Trend Following Strategies, Deep Learning

---

[1]通讯作者: 邱少健, qiushaojian@scau.edu.cn.

1. 引言

近年来，计算机科学技术与量化交易新相结合的新领域得到了良好的发展，人们整合股票市场中的技术分析和数据挖掘与人工智能来建立有利可图的投资组合[1]。诸如人工神经网络[2]，蜂群智能[3]和进化算法[4]等技术已经以各种方式应用于金融市场中。在资本市场上，股票、商品期货和对冲基金等金融投资产品的价格波动总是不确定的。它是一种含有自然噪声的随机行走的数学状态。利益相关者试图构建可靠的预测模型，以便在降低投资风险的同时获得更高的投资组合收益。而市场中是否存在可预测性是定量分析领域的投资者所感兴趣的。例如，预测股票价格未来走势和优化投资策略的其中一种方法是将经典的交易策略（如海龟交易法）和机器学习（Machine learning，ML）算法结合起来[5]。

许多学者对基于机器学习辅助的量化投资方向进行了研究并提出了许多新的方法。张剑华和王波[6]针对沪深300股指构建了一个基于支持向量机（SVM）的量化交易系统用于预测其涨跌趋势并把其转化为交易信号。在回测结果中显示，该交易系统在盈亏比方面表现较好，模型在暴涨暴跌中能够稳定地盈利。另外，Vats和Samdani[7]将神经网络、支持向量机、多核学习、随机森林法和K-Means聚类技术应用于股票市场预测。他们证明了聚类和非聚类技术都能在预测性能方面有良好的表现。论文还总结了每个模型的计算速度和效率，并证明了机器学习在实时应用于股票交易是可行的。除了机器学习有许多金融方面的实际应用之外，深度学习技术也被用于研究套利交易的机制当中。龙奥明等[8]提出在时间序列分析中使用协整检验和基于长短期记忆网络（LSTM）的方法对黑色金属期货（包括焦炭、铁矿石和螺纹钢）的价差趋势进行预测。实证分析表明，LSTM在时间序列预测性能方面优于BP（BackPropagation）神经网络和循环神经网络（Recurrent Neural Networks，RNN）。对四种交易策略的比较显示，LSTM神经网络在回测期普遍取得较好的收益。另一方面，隐马尔科夫模型是机器学习算法中关于时间序列的一个重要概率模型，同时，它也是一个黑箱模型，可以应用于预测商品期货市场的隐藏状态。然而，它的缺点是投资者不能直接知道当前状态是买入状态还是卖出状态。因此，能够预测交易方向的M-P（McCulloch-Pitts）神经元模型比前者更有优势。实证结果表明，在A股市场上使用基于M-P神经元模型的量化策略可以将基准收益率提高31.11%[9]。上述研究主要是通过机器学习或深度学习对传统的量化交易策略进行优化，让交易系统在金融市场上更具竞争力。

趋势跟踪策略是传统量化交易的重要组成部分，它是基于技术指标为短

期交易设计的动态通道策略[10]。在动荡的期货市场上，基于技术指标的交易策略的表现却有一些局限性[11]。例如，作为趋势跟踪策略的基础指标，移动平均线会出现误导性的穿越信号，而唐奇安通道也存在同样的问题。被称为 ”趋势跟踪之父 ”的理查德...唐奇安（Richard Donchian）在20世纪中期开发了唐奇安通道指标，以帮助交易者识别价格运动是否可能持续或逆转其方向。该策略是经典的趋势交易，是一个简单而通用的技术指标。它通常由三条移动平均线组成，上线，下线和被前两者围绕的中线。它的交易模式是识别一些价格突破，从而产生交易信号。不仅如此，这样的价格通道可以检测到趋势，市场波动的高点和低点，支撑和阻力水平，市场波动以及重要的突破口[14]。此外，Swart[15]在对南非期货市场的研究中，使用了基于唐奇安通道的趋势跟踪交易策略进行投资组合优化。在实证中发现，该策略在大多数情况下可以产生高收益，但在长期投资中缺乏良好的稳定收益，在面对市场风险时表现出较差的容忍度。

根据以往文献中指出的问题，本文提出了如图 1中所示的动机案例。尽管唐奇安通道可以识别一些交易机会，但在错综复杂的期货市场中，该策略并不总是适用。例如，当通道之间的宽度很窄，并且存在短期的市场冲击时，就很难捕捉到期货的价格趋势。频繁的通道价格突破将有可能导致系统连续在高价位买入，在低价位卖出，从而导致连续亏损和高额的交易成本。这就是普遍存在的通道的虚假突破的问题。因此，唐奇安通道在反转和震荡期间产生虚假的交易信号是其收益不佳的原因之一。

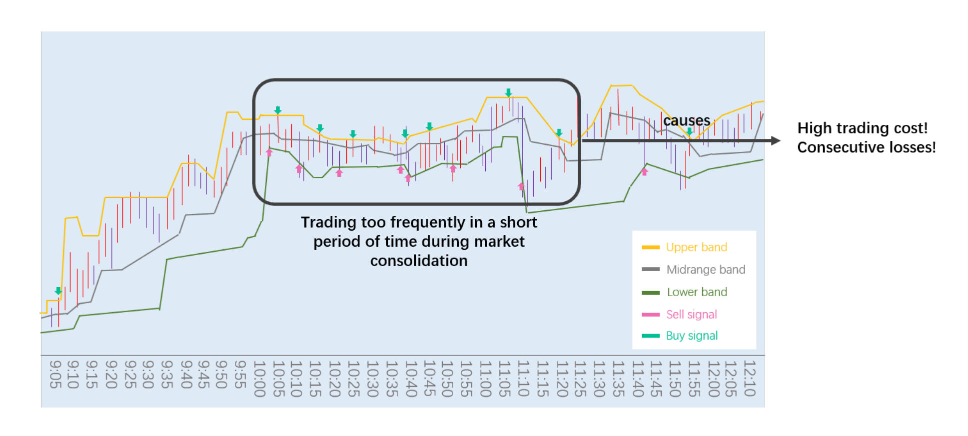


图 1. 动机案例

为了解决上述趋势跟踪交易系统的缺陷，我们使用机器学习技术来探索价格序列的变化规律。根据过去的价格轨迹，利用技术分析和金融时间序列分析对期货价格的上涨和下跌进行分类和预测。此外，基于LSTM的方法从

选定的技术指标和交易数据中提取特征[16]，由此产生的输出被用作机器学习分类器的学习特征。同时，趋势交易策略也会产生交易信号，这与分类器预测的收盘价格变动方向进行比较，如果两者产生相同的方向，那么就会指示着投资者做出相应的买入或卖出动作。虽然这样的组合信号可能有潜在的时效性问题，也就是等待技术指标和预测器指向同一方向，但在长期投资中，尤其是在价格盘整中，组合信号是相当可靠的。总的来说，这是我们提出的主要概念，用以过滤虚假交易信号，提高系统的整体性能。

综上所示，本文将通过使用基于LSTM提取的特征和机器学习的趋势跟踪交易系统，探索计算智能在量化交易中的应用。首先，尝试利用LSTM神经网络的信息可传递性，将这一技术应用于特征提取的环节中，以增进机器学习预测器的性能，也就是机器学习和深度学习的引入可以使技术指标交易系统具有更强的可预测性。其次，通过这样相结合的交易系统，证实人工智能技术与技术分析相结合的可交易性质，可以解决传统趋势交易中普遍存在的虚假信号问题。从而本文提出的交易信号过滤方法可以提高投资组合的盈利收益，它可以保持稳定的收益来应对股票市场的震荡期，并提高策略的抗风险能力。

2. 相关工作

期货作为一种金融衍生品，主要用于对冲现货市场带来的风险，是由远期合同发展而来的标准化合同。远期合同是与某人签订的的购买远期商品的合同，是以对冲为目的的协议。具体地，买方同意在规定的时间后以特定的价格接收资产，卖方同意在一段时间后以特定的价格交付资产。那么双方同意用于未来交易的价格被称为期货价格，而双方必须在未来交易的指定日期称为结算日或交割日。这样的标的物可以是某种商品（如黄金、原油、农产品），根据，每种商品的性质，期货的交割日期可以是一周后、一个月后、甚至一年后。到期后，标的物的现货价格便生成了，而期货价和现货价之间的差额乘以合同的数量就是各自的盈亏。在本次的研究中，非常重要的一点是，本文使用的是主力连续合约，也就是连续的、流动性最好的合约。其中，主力合约是是市场上最活跃、最容易交易的，交易量最大的合约。以螺纹钢期货为例，根据上海期货交易所的规定，流动性最强的合约是指每年1月、5月和10月的螺纹钢合约的期货价格。如果目前的主力合约接近交割日期，那么交易所会将未来交易更活跃的合约作为主力合约。这样它就永远不会交割，使交易者更容易研究。例如，如果当前是2021年11月，此时螺纹钢的主力合约是2023年1月。当日子越来越接近2023年1月合约的交割日期时，主力合约

将变成2023年5月的合约。另一方面，根据市场的长期变化规律，距离最近的交割月一个月到四个月的期货合约是最接近预期的现货价格，因此交易也最活跃。这样的合约被连在一起形成一个连续的价格序列，这就是连续合约。因此，螺纹钢主力连续合约数据就是由每年的1月、5月和10月的期货价格拼接而成的长期价格序列。使用这种方式的好处是，回测结果也更接近于实际交易情况。而在如今十分成熟的期货市场中，期货合约，期货交易所、保证金、开仓和平仓等已成为市场运作的重要组成部分。交易者们也随着环境的进步尝试摸索出一套分析市场趋势的方法用以预测未来的趋势，这就是技术分析。

技术分析，如技术指标，是依靠历史的价量信息来预测股市趋势的一套方法[18]。使用技术指标进行趋势交易已被许多交易者证明是最有利可图的工具之一，并已被用作股票指示买卖信号的指标[19]。Han等[20]提供的证据表明，在构建商品期货投资组合时，使用简单的移动平均线计时策略在美国商品期货市场上可以非常稳健地盈利。Clare[21]也证明了这些趋势交易可以在美国商品期货市场上产生显著的平均超额收益。然而，一些研究人员发现，技术分析在中国期货市场的表现与其他国家或地区不同。因为中国有独特的期货市场模式，个人投资者在中国期货市场上占了大多数。因此，Li[22]指出，在中国期货市场上应用的趋势跟踪策略的表现不如在美国期货市场上的表现好，这体现在前者的年平均超额收益较低。而学者们指出的问题与本文探索的方面是一致的，因此，为了使趋势策略有更好的表现，本文将引入机器学习和深度学习技术来实现更高的利润。

机器学习和深度学习的优势在人工智能领域的蓬勃发展中逐渐显现。与传统的技术指标策略相比，尽管后者具有趋势预测性，但从长期投资的角度来看，这种策略在面对复杂的市场波动时很难与之对抗。相反，近年来，学者们在计算机科学领域中提出了多种多样的预测模型。对于股票市场中产生的大量非线性数据，需要通过更有效的模型来识别隐藏的模式和复杂的关系，而这可以通过人工智能技术得到实现。同时，事实证明，与技术分析或基本面分析相比，机器学习技术可以提高60-86%的交易效率[23,24]。

目前，人工智能技术正在各个领域迅速发展。许多基于人工智能的交易规则正被应用于全球股票市场中，例如结合技术分析和机器学习和深度学习进行交易，试图用这些技术来增强已经流行和广泛使用的传统算法。Sang[25]实验了用于预测的趋势指标，包含简单移动平均线（Simple Moving Average，SMA）、相对强弱指数（Relative Strength Index，RSI）和移动平均收敛背离（Moving average convergence divergence，MACD），并在这三个技

术指标交易方法中分别引入LSTM进行实验。实证表明，在传统技术分析中应用神经网络后总利润有了明显的提高。更有甚者，Ayala[26]提出了一种将技术指标与机器学习方法结合起来产生交易决策的过程。经过训练线性模型（Linear Model，LM）、人工神经网络（Artificial Neural Network，ANN）、随机森林（Random Forests，RF）和支持向量回归（Support Vector Regression，SVR）后选择出具有最高预测能力的模型。此外，还分别比较了三重指数移动平均线（Triple Exponential Moving Average，TEMA）和移动平均收敛/背离（MACD）策略。挑选出表现最好的机器学习模型和技术指标策略，将两者结合起来并提出新的交易规则。实证结果显示，这种混合模型提高了每个策略的盈利能力，并减少了交易次数从而较少交易成本的付出。

综上所述，众多研究者发现了神经网络在量化金融中蕴含的强大力量，并通过多次实验证明了神经网络在预测股票和商品期货价格方面的可行性。但是，这并不能概括地说，神经网络的价格预测性能优于传统的技术指标，而且不能因为深度学习技术的流行性而否机器学习技术的性能。因此，本文将更精确地利用LSTM神经网络的信息传递方式的特点，利用它对数据特征进行合理提取，并将机器学习模型作为预测器来预测期货价格的运动方向。换句话说，本文的研究目的是利用机器学习和深度学习技术来提升传统技术指标的趋势预测能力。

3. 研究方法

3.1. 方法背景和原理

3.1.1. LSTM神经网络原理

LSTM是一种神经网络，是循环神经网络（RNN）的变种，可用于处理时间序列，具有记忆长、短期信息的能力[27]。它通过门控将短期记忆与长期记忆结合起来，解决了RNN由于梯度消失和梯度爆炸的问题而产生的长期依赖性[28]。梯度消失的主要原因是计算递归导数。LSTM可以解决该问题，并允许任意长距离的依赖关系之间的学习。简而言之，这意味着与RNN相比，LSTM在长序列中能够有更好的表现。此外，LSTM的门机制可调节信息流，从而删除或修改细胞状态的信息，为信息有选择地传递下去提供路径。具体地，它由sigmoid层（sigmoid layers）、双曲正切层（hyperbolic tangent layers）和点对点的乘法运算（point-wise multiplication operations）组成[29]。LSTM引入了可计算的记忆单元，可以有效地将记忆和输入进行远程关联，因此它可以动态地掌握数据的结构并保持较强的可预测性。每个单元的关键

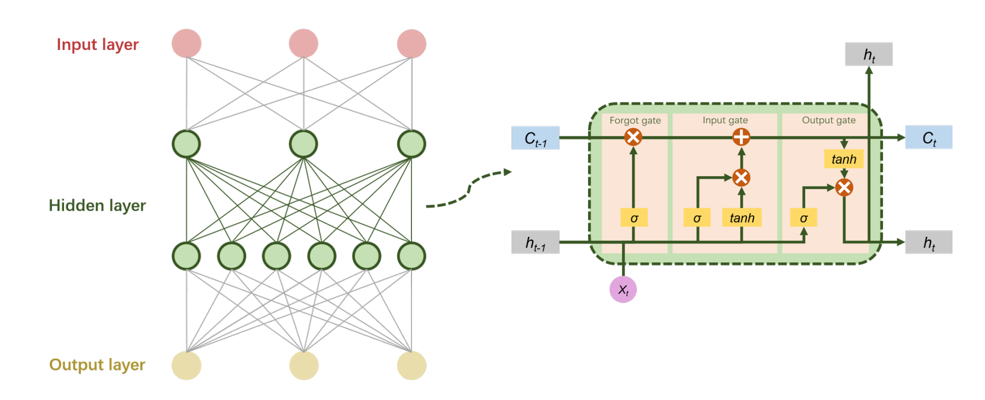


图 2. 长短期记忆网络结构和记忆单元结构

组成部分是一个输入层（input layer）、一个隐藏层（hidden layer）和一个输出层（output layer），图 2展示了LSTM架构，以及计算方程如下：

$$
\begin{aligned}
f_t &= \sigma(W_{fh}h_{t-1} + W_{fx}x_t + b_f) \\
i_t &= \sigma(W_{ih}h_{t-1} + W_{\tilde{c}h}x_t + b_i) \\
\tilde{c}_t &= \tanh(W_{\tilde{c}h}h_{t-1} + W_{\tilde{c}x}x_t + b_{\tilde{c}}) \\
c_t &= f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \\
o_t &= \sigma(W_{oh}h_{t-1} + W_{ox}x_t + b_o) \\
h_t &= o_t \cdot \tanh(c_t)
\end{aligned}
\tag{1}
$$

其中， $\mathbf{c}_t$ 是时间 **t**的单元状态, $\mathbf{h}_t$ 隐藏状态, **W** 为权重; $\mathbf{i}_t$, $\mathbf{f}_t$,and $\mathbf{o}_t$分别是输入门，遗忘门和输出门; $\mathbf{b}_f$是偏差; $\boldsymbol{\sigma}$ 是sigmoid激活函数; **tanh** 是tangent激活函数; $\mathbf{x}_t$是当前输入 [31].

值得注意的是，在方程 1中，当前时刻的单元状态$\mathbf{c}_t$是由前一个单元状态$\mathbf{c}_{t-1}$被遗忘门$\mathbf{f}_t$乘以其元素，然后当前输入单元状态$\tilde{c}_t$被输入门$\mathbf{i}_t$乘以其元素，然后两个乘积相加。这样，当前记忆$\tilde{c}_t$和长期记忆$\mathbf{c}_{t-1}$可以结合起来，形成新的单元状态$\mathbf{c}_t$。这样计算的好处是，由于遗忘门的控制，它可以保留很久以前的信息，同时由于输入门的控制，它可以避免当前不相关的内容进入记忆。因此，本文利用LSTM这一特性探索长序列中的有效特征选择采用基于LSTM的特征提取方法。这样做的原因有两个。首先，为了确认基于人工智能的价格预测器是可交易的，必须考虑到预测结果可以在实际交易中使用。结合计算速度和期货价格的实时生成速度，在这种情况下选择做长序列预测

是合理的。其次，LSTM神经网络具有信息可传递性，可以保留长序列中有效的特征。

3.1.2. LSTM神经网络的特征提取方法

本文将通过基于LSTM的网络使用特征提取方法来降低数据维度，并从杂乱的信息中提取有用的特征。模型的输入包括期货的历史价格序列、技术指标和从价格序列中提取的时间序列特征。这些输入将被LSTM进一步处理，而提取后的输出被用作机器学习分类器的学习输入。最终使用这些提取的有效特征来训练分类器模型并预测期货价格的涨跌趋势。本文提出的方法如图3。

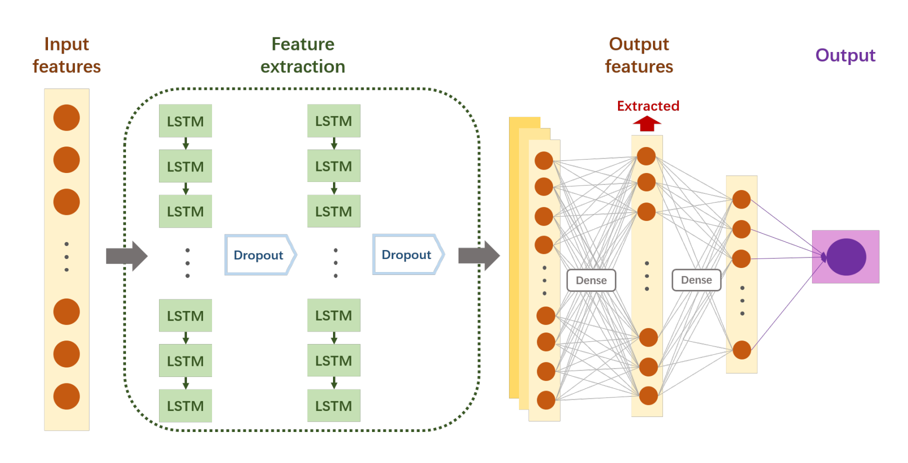


图 3. 基于LSTM的特征提取机制

一个输入层、两个LSTM层、两个全连接层和一个输出层是这个网络结构的基本组成部分。然而，神经网络有两个潜在的问题可能会影响模型的训练任务。一个是梯度消失，导致收敛困难，另一个是过度拟合的问题，导致测试集上的性能表现不佳。因此，本文在每个LSTM层之后加入了Dropout层，即在每次训练的时候，随机让预设数量的神经元停止工作，目的是提高LSTM网络的泛化能力。得注意的是，虽然输入数据已经通过LSTM和Dropouts的计算被提取出来，但特征仍然需要通过全连接层进行扁平化处理。

3.2. 研究设计

3.2.1. 基于机器学习过滤器的趋势跟踪交易策略

我们通过以下三个步骤构建了一个基于机器学习的趋势跟踪交易系统。 1) 构建机器学习预测器，旨在利用期货的历史数据预测价格涨跌趋势。具体过程在章节 3.2.2中讨论；2) 趋势交易策略的构建，使用该策略生成交易信号。主要概念在章节 3.2.3中呈现； 3) 趋势交易策略和分类器的组合，新的交易规则使用步骤（1）中产生的预测值与步骤（2）中的交易信号进行比较，也就是用基于机器学习的模型过滤交易信号。提出的具体方法将在章节 3.2.4中讨论。

总体构建过程如图 4所示。

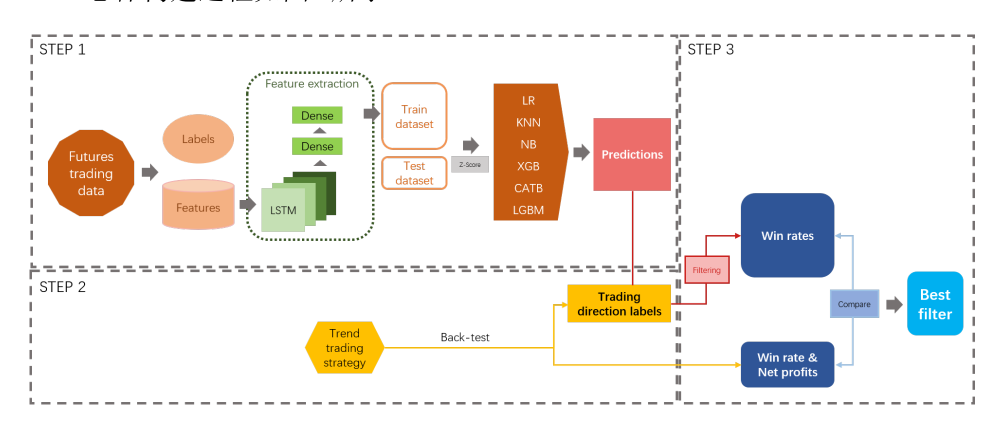


图 4. 基于机器学习过滤器的趋势交易策略流程

首先，需要对价格预测的总体框架进行构建。获取期货历史数据作为基础数据，所i后用于标签和特征制作。具体来说，价格涨跌幅是通过收盘价序列计算出来的，确定涨跌的阈值则参考了止损机制，因为交易策略中普遍会放置保护性止损。从而预测目标被映射到两个类别（涨，跌），这便是模型的标签，用以执行二分类任务，其计算公式为

$$r_t = \frac{p_{t+1}}{p_t} - 1 \tag{2}$$

$$P(t) = \begin{cases} 1, & r_t \leq 0.01 \\ 0, & r_t \geq -0.01 \end{cases} \tag{3}$$

其中，$\mathbf{r}_t$ 是t时刻的涨跌比率, $\mathbf{p}_t$是t时刻收盘价， 1%是止盈点，-1%是止损点，两者是定义涨跌的阈值，$\mathbf{P}_t$ 是价格的涨跌方向，’1’ 是涨而’0’是跌。

此外，从期货数据中计算的技术指标可以作为特征组之一。因为在金融数学领域经常提到时域的可观察性，所以从价格的历史轨迹中也可以提取出时间序列特征作为模型的特征组。因此，本文采用三组特征分别是基础数据特征，技术指标特征和时间序列特征。采用LSTM神经网络对这些特征组进行提取后，数据集按照滑动窗口的方式划分训练集和测试集，分别对这些样本做标准化处理，然后将其应用到六个不同的机器学习分类模型中进行训练、预测以及结果评估。

预测模型的框架确定后，下一个任务是编写一个趋势跟踪交易系统。许多投资者认为，历史数据可以为未来的价格走势提供指示，因此由技术分析得出的交易规则已经成为许多交易者关注的焦点[39]。因此，本文在设计交易规则时采用了普遍交易者选定的参数，基于唐奇安通道指标的基本交易规则编写了一个趋势跟踪交易系统。通过选定一个周期参数来绘制通道，从而产生的交易信号。最后，这一步产生的交易信号与分类器预测的值相结合会得到最终的交易方向。这个结合的交易系统的性能表现可以通过回测进行评估。

3.2.2. 基于LSTM的特征提取和机器学习分类器

期货的价格变动符合金融时间序列的性质，也就是资产价值随着时间的推移而变化。因此，机器学习模型能够捕捉到价格上涨和下跌的交易信号。整个构建过程如图 5所示。

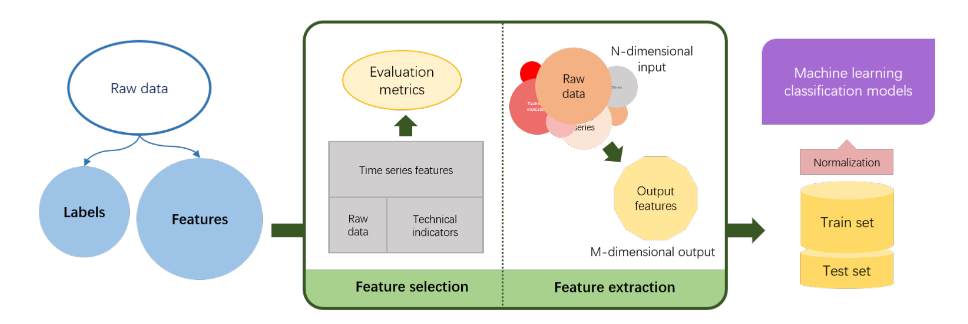


图 5. 机器学习模型构建流程图

首先，获取期货的历史价格数据，包含收盘价、开盘价、最高价、最低价和交易量。这五种属性作为原始基础数据集，并计算收盘价制作分类标签。在特征工程阶段中，如果只使用基础数据训练模型可能会暴露学习能力差和模型复杂度低的缺点，从而导致过拟合的问题。因此，为了构建更丰富的特征组，本文参考Dvoryatkina[34]的方法，使用技术指标为特征，并通过TA-

Lib库[35]进行计算，而这些是由价量信息计算出来的。使用技术分析来预测期货价格趋势是有一定的优势，例如它有广泛的使用范围并对所有类型的交易总是有效。同样地，时间序列中隐含的特征也十分重要，比如使用自回归条件异方差法在预测股票时涉及方差和波动率。因此，本文使用TsFeatures来计算时间序列分析的相关特征，并在随后的实验中证明其有效性。通过以上的计算，三组特征便组建好了，但这样的特征组数据量大且并不是每个特征对模型的训练都有贡献。因此，本文设计实验来比较特征组的组合，并选择最优组合作为特征提取步骤的输入数据。经过选择合适的特征组后，需要进行LSTM神经网络提取特征，使原来112维的输入数据减少到16维的输出。考虑到期货价格的强时间序列特性，随机抽样的数据集划分的方法并不适用。因此，在特征提取后采用滑动窗口法对数据集进行划分[33]。

随后，采用Z-Score标准化的方法统一特征组的量纲。在预测阶段，本文使用六种机器学习模型作为分类器来预测期货的价格趋势，包括逻辑回归（Logistic Regression，LR）、k-近邻（k-Nearst Neighbors，KNN）、朴素贝叶斯分类器（Naive Bayesian Classifier，NBC）、XGBoost、CatBoost和LightGBM分类器。在比较分类任务的性能时，还需要使用混淆矩阵来计算准确率（Accuracy，ACC）和F1分数来评估预测结果。

3.2.3. 唐奇安通道交易策略

唐奇安通道指标是从海龟交易规则演变而来，海龟交易规则是理查德...唐奇安在1950年开发的一个强大的趋势跟踪指标。它作为一种辅助交易的工具经受住了时间的考验，被常用于商品期货和股票交易中。唐奇安通道的原理并不复杂，当价格在通道的中间和顶部之间时，它代表着趋势是上升的。当价格在通道的中间带和底部之间时，它表示趋势是下降的[36]。本文使用两个通道，上轨和下轨，其计算方法如下

$$\begin{aligned} \textbf{Upper} &= \max(H,N) \\ \textbf{Lower} &= \min(L,N) \end{aligned} \tag{4}$$

Upper 上轨是由过去N条价格序列的最高价H形成的，相反，**Lower**下轨是由过去N条价格序列的最低价L形成的。该系统的交易规则是如果最新价向上突破了上轨时，则发出买入信号；反之，如果最新价向下穿过了下轨时，则发出卖出信号。。同时，该策略需要考虑滑点值（即实际交易价格和预设交易价格之间的变化量）和止盈止损机制，在已经持有多头或空头的情况下，如果盈利比率上升到一定的百分比（如1%），就关闭多头或空头，这样的机制与标签制作中的阈值设置相对应。

3.2.4. 基于机器学习分类器和唐奇安通道交易系统的交易规则

一个结合了预测器和技术指标的交易系统会产生一个新的交易规则。根据唐奇安通道的交易系统，该策略在回测期间产生买入和卖出信号，多头信号被标记为'1'，空头信号被标记为'0'。在同一交易时刻，机器学习预测器产生的上升趋势（'1'类）和下降趋势（'0'类）的价格变动预测值。如果策略和预测器都产生'1'的信号，那么指示着投资者买入；如果是'0'，指示着投资者卖出。这就是交易信号的过滤规则，只有当信号是基于唐奇安通道产生，并且预测器也指向相同的方向时，才会持仓。

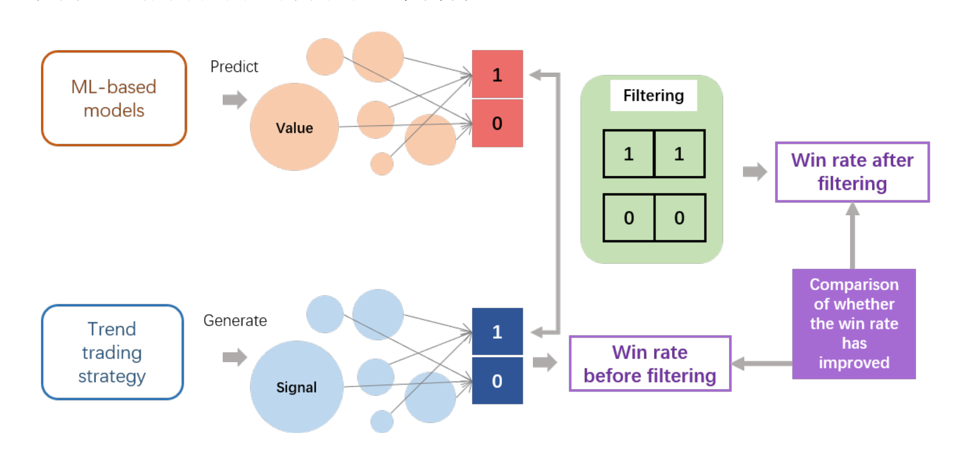


图 6. 机器学习和趋势交易策略的系统性结合

从经济表现来看，对基于机器学习方法的交易系统进行评估也是至关重要的。回测可以将原始策略的表现与过滤后的策略的表现进行比较。通过比较使用基于机器学习方法前后的胜率、净利润、收益率、年化收益率、最大跌幅、恢复系数（即净利润与最大跌幅的比率）、总利润和总交易次数来评估预测模型的应用是否带来了积极的经济效益，如图 6。同时也用这些标准从6个不同的分类器中选择适合当前策略的分类器，主要对比胜率和总利润。

4. 实验

实验设置分为三个主要部分。第一部分是特征选择，这是特征工程的一个重要步骤。其目的是选择适合训练模型的特征组。在这一步中，分别使用时间长度为三个月和六个月的价格数据，对由不同特征的组合进行实验。使用F1-measure和准确率作为评价标准。最后选出符合模型的特征，并列出有代表性的特征且用实例加以说明，具体内容见第章节 4.2。第二部分是预测模型实

验的设置。实验设置从建立LSTM模型开始，从章节 4.2的实验中选出的特征组被输入到LSTM模型。随后进行数据集划分和归一化处理。完成上述设置后，进入机器学习预测环节，最后得出分类器预测值和评价分数。第三部分是唐奇安交易系统的参数设置和策略回测，此步将生成交易信号和回测评价分数。

执行上述步骤后，得到的实验结果有以下几个运用目的。执行上述步骤后，我们得到的实验结果有以下几个目的。首先，六个不同的ML分类器的F1分数和准确率表现可以帮助我们选择目前表现最好的预测器。第二，将唐奇安指标产生的交易信号与所选分类器产生的预测信号进行比较。为了获得使用基于机器学习的信号过滤器后的唐奇安交易系统的胜率和净利润，这两个回测指标与章节 4.3中交易系统的回测结果进行比较，观察信号过滤器是否有助于唐奇安交易系统提高其经济绩效。

4.1. 数据集

数据集包括具有复权价格的螺纹钢期货（上海期货交易所），使用主力连续合约，交易日在2016年1月至2022年6月之间，共108,000条5分钟K线数据。另外，为了进一步验证本文提出的系统的可行性，使用黄金（上海期货交易所）和豆粕（大连商品交易所）期货的数据进行更多的实证分析。预测的目标设定为两类标签（上涨，下跌）。

4.2. 特征选择

基于TA-Lib开源库计算出112个技术指标特征和Kats工具库中的TsFeatures库计算出46个时间序列特征。最终，由基础特征组，技术指标特征组和时间序列特征组构成所有特征数据。每个类别分别列出代表性的指标并给出了一些详细的例子，但并不是所有的112个指标都被列出，具体特征表 1所示。

这里讨论了六类技术指标。重叠研究类中包含最多的是移动平均线，它是技术分析中最常见的指标类型。以几个指标的详细解释为例[37]。

MA5 （移动平均指标）是指连续的5个时间间隔的价格平均值。

BBANDS (布林带指标）是根据统计学中的标准差原理设计的，它包括中轨、上轨和下轨。

动量指标旨在分析股票价格波动的速度，研究波动过程的加速、减速和惯性，以及股票价格由动转静或静转动的现象。

RSI （相对强弱指标）通过衡量股价总涨幅占一定时期内股价总变化平均值的百分比来评估多头和空头的力量。该震荡指标表明最近价格是否上涨或下跌过快[38]。

成交量指标使用成交量数据来计算其运动趋势，从而推断出股价的趋势。

OBV （能量潮）是由OBV值和OBV线组成。它主要用于判断量价关系，即OBV曲线是否与股价运动方向一致。

波动指标是指金融资产价格的波动程度，是衡量资产收益的不确定性，用于反映金融资产的风险水平。

ATR （平均真实波动范围）是在一定时期内对价格移动平均线进行平均化后的交易波动率。

表 1. 三组特征组及其分类

特征组	特征类型	特征名称	数量
基础特征	-	收盘价，开盘价，最高价 最低价，成交量	5
技术指标	重叠研究	MA5, EMA, BBANDS, SAR, TEMA, WMA 等	112
	动量	MACD, ROCP, RSI, ADX, APO, CCI, MFI, WILLR 等	
	成交量	OBV, AD, ADOSC	
	波动率	ATR, NATR, TRANGE	
	价格转换	AVGPRICE, MEDPRICE, TYPPRICE, WCLPRICE	
	周期	HT_DCPERIOD, HT_DCPHASE, HT_PHASOR, HT_TRENDMODE	
时序特征	-	均值，方差，香农熵 KPSS单位根检验，自相关系数， 自相关方程, 偏自相关方程，季节性程度， 尖锐性等	46

本文设计了两组实验来选择特征组。第一组实验用6个月的数据作为训练集，用2个月的数据作为测试集。分割训练集和测试集的方法是滑动窗口

法，其具体含义在章节 4.3中提到。第二组实验使用13个月的周期数据作为训练集，同样，测试集的周期为2个月。换句话说，用不同时间长度的训练集来训练模型，但测试的是同样时间长度的周期。每组实验有四个变量，'base'、'base_kats'、'base_ta'、'base_ta_kats'，分别指基础数据、基础数据和时序特征、基础数据和技术指标，以及基础数据和时序特征和技术指标。

为了达到更好的预测效果，我们使用了与最终实验设置相同的ML模型，即LR、KNN、NBC、XGBoost、CatBoost和LightGBM分类器，并使用F1-Score、ACC和AUC（曲线下面积）作为评价指标来协助选择特征集。以实验1的'base'组为例，在特定的时间内使用该特征组训练了六个不同的分类器，会得到2021年1月1日至2022年7月1日的测试集评价结果。这样的结果总共有10组，取这些结果的平均值后，可以得到6个分类器中每个分类器的基于'base'特征组训练的性能表现。根据F1-Score、ACC和AUC分别取所有分类器的平均值，可以得到'base'特征组在这三个指标上的表现。这两个实验的结果如图 7所示。 根据实验结果，无论是使用时间长度为13个月的训练集还

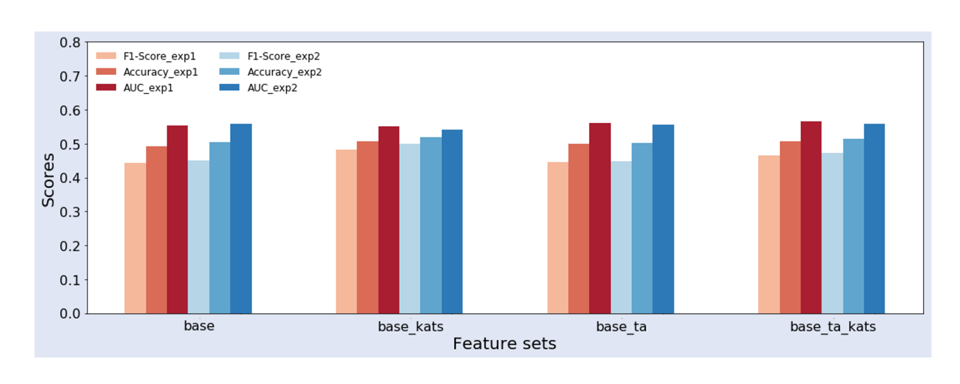


图 7. 特征选择的实验结果

是6个月的训练集，'base'组的F1值都比较低，还没有达到0.5。虽然AUC值表现突出，但我们不考虑只使用基础数据作为特征的情况。在F1值方面表现不佳的还有'base_ta'组，尽管它比'base'组有进步，但不能与其余两组相比。从直方图上看，'base_kats'组在三个评价分数中都表现平均，这意味着它在很多维度上都有良好的表现。'base_ta_kats'组的表现也不差，从具体数值上看，两个F1值和准确率的差别非常小，但从AUC上看，后者的得分更高。除了需要考虑上述实验结果，深度学习神经网络需要通过大量的数据进行训练，所以最终选择了'base_ta_kats'（有163个维度）作为特征组，该数据集包括历史价格数据、技术分析指标和时间序列特征。

4.3. 模型实验设置

本文使用Python3.7.0，Scikit-Learn用于机器学习技术，PyTorch用于深度学习训练任务。代码运行环境如表 2所示。

表 2. 系统环境

CPU	Intel(R) Core(TM) i7-10700K
RAM	32.0 GB
GPU	NVIDIA GeForce RTX 2080 SUPER
System	Windows 10
Python Version	Python3.7.0
Scikit-Learn Version	1.0.2
PyTorch Version	1.6.0
CUDA Version	11.7.101

预测模型的总体实验流程如图 4所示。在获得期货价格数据后，利用这些数据产生特征和标签。其中，产生的特征需要进行特征选择，这是章节4.2的实验结果，使用'base_ta_kats'组作为特征组。接下来，经过特征提取后，这些提取的特征被输出作为机器学习预测器的学习特征。采用滑动窗口划分法使特征组和标签被分为训练集和测试集。随后，这两个数据集被分别归一化，学习特征便被送入分类器进行训练产生最终的预测值。

LSTM网络的主要结构包括一个输入层，两个LSTM层，每个层后面有一个Dropout层，Dropout率设置为0.1，且采用Softmax作为激活函数，具体参数见表 3。神经网络使用Mini-Batch方法来训练模型，选择一定量的数据进行训练，然后计算损失函数，更新梯度，这样就没有复杂的计算，也就避免了训练缓慢的情况。将epoch的大小设置为50，batch大小为32，用于训练样本。在每个epoch中，从训练集中选取32个样本进行训练，直到训练集中的所有数据都训练完毕，然后再使用下一个epoch。交叉熵损失函数被用作损失函数来衡量输出标签和真实情况之间的差异。本文参数的设置与参考龙奥明[8]的文献。

其次，将数据分为训练集和测试集的方式是滑动窗口划分法。这是一种划分时间线的方法，它根据指定的单位长度来框定时间序列，每个滑动窗口为一个单位。本文设置步长为2个月，窗口大小为13个月，换句话说，预测值是递归产生的，每次会产生2个月的预测范围。具体来说，初始数据点为2016年12月1日，此后13个月内的数据为第一个训练集，标记为 'train1'；2018年1月1日至3月1日为第一个测试集，标记为 'test1'。同

表 3. 深层LSTM神经网络的具体参数

Parameters	Values
LSTM-layer1 hidden_size	60
LSTM-layer2 hidden_size	65
Dense1 out_features	16
Dense2 out_features	2
Dropout rate	0.1
Activation	Softmax

样，2017年2月1日开始后13个月的数据为第二个训练集，标注为'train2'；2018年3月1日至2018年5月1日的数据为第二个测试集，标注为'test2'。以此类推，直到整个数据集划分完毕。具体情况见图

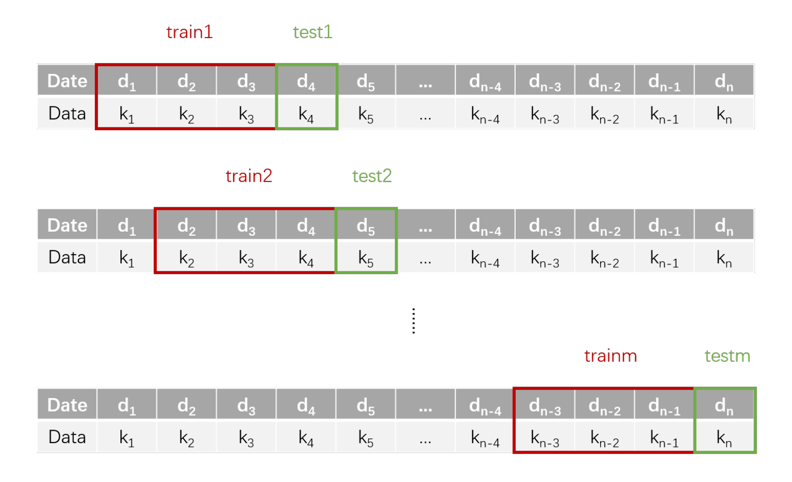


图 8. 滑动窗口划分数据集方法

利用2016年12月1日至2022年7月1日的数据，用这种方法将数据集分为27组（特定周期的测试集和训练集为一组），也就是会产生27组预测数据。以防信息泄露，需要分别对测试集和训练集进行Z-Score标准化。详细来说，对于样本序列 $x_1, x_2, x_3, \ldots, x_n$ 要根据以下公式进行标准化

$$y_i = \frac{x_i - \bar{x}}{s} \tag{5}$$

其中 $\bar{\mathbf{x}}$为样本平均数，**s**为样本标准差，$\mathbf{y}_i$为平均位置为0，方差为1，无量纲的数据。如果在细分数据集之前，先从整个数据集计算出样本均值和样本标准差，那么训练集就包含了测试集的信息，而测试集的数据也包含了训练集

的信息。反之，如果对训练集和测试集分别进行归一化操作，就可以避免上述情况。

最终，这些标准化的数据被送入六个不同的机器学习分类器进行预测，且使用F1-measure和准确度值对生成的预测进行评估。

4.4. 唐奇安交易系统设置

在实验中，唐奇安通道指标中设置N=24作为上下轨的计算参数。同时，该策略的交易条件为1%止损点，滑点成本为1元人民币。在回测期间使用与测试集相同的时间，即2018年1月1日至2022年6月30日。参数设定后，对策略进行回测，然后产生交易信号。这些结果直接与机器学习预测结果整合，比较两者的交易方向，从而完成了信号过滤。同时，生成的回测报告的评价指标包含胜率、净利润、收益率、年化收益率、最大跌幅和净利润与最大跌幅的比率。

5. 实证分析

章节 5.1和章节 5.2是以螺纹钢期货为例对实验结果的详细分析，而章节 5.3是基于前两节的分析过程，利用黄金和大豆期货的价格数据对本文提出的系统进行更多的实验。

5.1. 机器学习分类器的预测性能表现

每个模型的平均准确率和F1值是由27个测试集的评估分数得出的，同时也观察其标准差，详细结果如表 4所示。综合所有时期的结果，逻辑回归分类器在所有分类器中表现最好，准确率值为52.952.9%，然而F1-Score是最低的，只有43.1%，这说明LR分类器只能在某些时期表现特别好，但不稳定。除了平均ACC分数最低的KNN分类器和LR分类器，其他四个分类器的表现相对均衡，可以作为候选分类器。综合所有分类器，他们的准确率都在50%以上，这是一个可观的效果。

考虑到不同时间段的金融市场总是受到国家经济政策、地缘政治事件以及其他宏观或微观的影响，分别观察27个时间段的预测结果更为合理，如图9所示。

对于准确率来说，除了预测时间在 2019年9月1日的准确率只有0.40，其它大部分时间内，分类器准确率基本可以达到0.50以上。表现最好的两个时间段是2020年9月和2021年1月，分类器准确率高达0.60及以上。其中，表现

表 4. 螺纹钢期货数据在逻辑回归(LR), k-近邻(KNN), 朴素贝叶斯(NBC), XGBoost(XGB), CatBoost(CATB)和LightGBM(LGBM)分类器的评估分数

Classifier	LR	KNN	NBC	XGB	CATB	LGBM
ACC	0.529±.058	0.501±.021	0.520±.042	0.518±.025	0.519±.042	0.518±.044
F1-Score	0.431±.061	0.493±.017	0.462±.042	0.493±.014	0.471±.032	0.466±.032

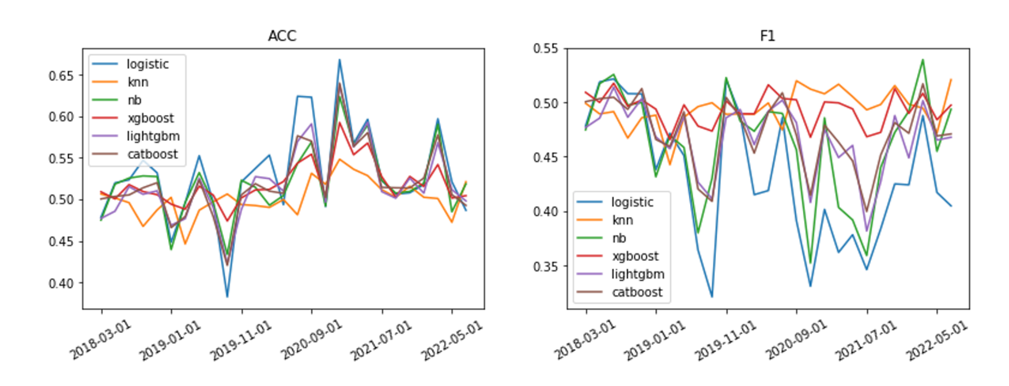


图 9. 每个时间段的机器学习模型的准确率和F1分数（螺纹钢期货）

最好的是逻辑回归分类器，其 ACC值大于0.65。但由于逻辑回归分类器在所有时间段中处于峰值也处于低谷，所以表现并不稳定。而KNN的整体分数都较低，所以在选取最终使用的分类器方面考虑首先排除这两项。除了参考准确率以外，分类模型通常使用F1分数作为模型评估标准之一。F1分数是精确率和召回率的调和平均数。在图 9中可以总结出整体F1分数在0.50左右，而逻辑回归和朴素贝叶斯分类器的表现异常，且在多个时间段中分数只达到0.35。反而在F1评估指标中KNN分类器和XGBoost分类器表现比较稳定，均在0.45至0.50之间浮动。结合ACC和F1-Score的平均值以及分时段的评估结果，CatBoost和XGBoost分类器的表现更佳。

5.2. 基于机器学习分类器的交易系统绩效评估

除了需要参考模型评估分数之外，还需要考虑胜率和净利润作为模型性能的评估标准。如表 5所示，没有过滤的历史回测，即只使用唐奇安通道交易策略所产生的胜率为40.58%（包含0.03%的交易费用），利润仅为9216.23元。使用了机器学习框架作为过滤器后，除KNN模型过滤器的胜率和净利润不升反降外，其他五个过滤器构建的策略均在胜率上有提升，具体体现在盈利能力上，平均净利润涨幅达103.13%。其中，XGBoost 过滤器产生了最高的胜率和

表 5. 唐奇安交易策略和基于不同分类器的唐奇安交易策略的胜率和净利润（螺纹钢期货）

分类器	胜率 (%)	净利润 (RMB)
无过滤	40.58	9,216.23
LR	44.29	18,606.37
KNN	40.21	7,148.43
NB	43.48	16,948.39
XGB	**44.64**	**27,675.19**
CATB	41.57	14,776.60
LGBM	42.19	15,596.11

盈利，净利润达到 200.29%的涨幅。整体而言，胜率有所提升的同时盈利也产生了较大改变，所以 XGBoost 模型也达到在整体市场价格走势中稳定盈利的目的。

选择出基于XGBoost过滤器的唐奇安通道交易策略作为螺纹钢合约的最优中长期预测模型后，根据回测报告可计算出更多指标评估模型效果。具体如表 6，收益率增长达60.19%，年化收益率由6.39%提升到15.68%，说明该模型显著地提高了投资的回报率，且指导投资者可在资产分配中投入更多的资源。同时，最大资产回撤的回撤幅度降低了63.85%，表明XGBoost过滤器可以使唐奇安交易系统有较好的收益稳定性和抗风险能力。

表 6. 基于XGBoost过滤器的策略绩效评估结果（螺纹钢期货）

回测指标	无过滤	基于XGB的交易系统
胜率	40.58%	44.64%
净利润	9,216.23	27,675.19
收益率	32.03%	92.22%
年化收益率	6.39%	15.68%
最大资产回撤(RMB)	9,361.25	3,383.97
净利润/最大资产回撤	1.03	8.18

从2018年1月到2022年6月的回测报告中绘制的资产曲线如图 10所示。红色曲线是使用XGBoost分类器过滤后的策略，曲线显示出稳定上升的趋势。蓝色曲线是没有过滤的策略，呈现一个缓慢地逐步上升的趋势，虽然在回测周期内也是盈利的但并不持续。特别是在2020年6月和2021年6月之间，蓝色曲线显示了一个低谷，然后是一个大的跳跃，这对于希望长期有稳定回报的投资者来说是不利的。绿色曲线是前两者的价差序列，这表示在盈利能力方面，有XGBoost的交易系统与没有XGBoost的交易系统有较大的差距。结合

图表和回测指标可以得出结论，使用XGBoost过滤器的策略更加稳定和高效，同时也表现出了出色的抗风险能力。



图 10. 基于XGBoost的唐奇安通道交易系统的资产曲线（螺纹钢期货）

5.3. 黄金和豆粕期货的实证分析

以螺纹钢期货为例，从章节 5.1和章节 5.2中可知，选择表现最好的机器学习模型后将选定的模型整合到技术分析策略中进行回测。同样地，使用同样的分析过程来分析黄金和豆粕期货的实验结果。

表 7. 黄金和豆粕期货数据在逻辑回归(LR), k-近邻(KNN), 朴素贝叶斯(NBC), XGBoost(XGB), CatBoost(CATB)和LightGBM(LGBM)分类器的评估分数

期货	分类器	LR	KNN	NB	XGB	CATB	LGBM
黄金	ACC	0.526±.127	0.511±.067	0.530±.114	0.522±.080	0.523±.106	0.522±.095
	F1-Score	0.435±.093	0.481±.048	0.457±.082	0.474±.052	0.454±.075	0.461±.064
豆粕	ACC	0.494±.065	0.494±.027	0.491±.042	0.492±.033	0.488±.041	0.489±.039
	F1-Score	0.468±.053	0.488±.027	0.477±.037	0.486±.031	0.479±.035	0.481±.035

机器学习分类器的F1值和准确率的结果见表 7。在6个分类器中，在黄金的数据上进行实验的表现明显好于豆粕，每个分类器的27个测试集的平均精度大部分都达到了52%以上而只有KNN分类器的表现稍差，这与螺纹钢期货的情况相同。相反，NB模型的结果最好，准确率达到53%。从F1衡量标准来看，KNN是最好的而NB的表现并不十分突出。在这种情况下，优先考虑选择

准确率作为标准。另一方面，与黄金相比，所有分类器对豆粕期货的ACC平均值来说表现一般，但整体的F1分数却比黄金的好。其中，KNN的两个评估结果最好，准确率和F1分数分别为49.4%和48.8%。因此，KNN分类器被选为回测豆粕期货的唐奇安交易系统的过滤器。

尽管对比每个分类器应用到策略的绩效表现是合理且十分可行的，但考虑到实际应用方面，将每个分类器与交易策略结合起来再进行回测是很耗时的。因此，我们直接选择模型性能评估中表现最好的分类器，然后把这个过滤器放到交易策略中进行回测。实验中使用过滤器前后的黄金和豆粕期货的绩效表现见表 8和表 9.

表 8. 基于NB过滤器的策略绩效评估结果（黄金期货）

期货	回测指标	无过滤	基于NB的交易系统
黄金	胜率	34.96%	36.53%
	净利润	47,323.07	90,898.48
	收益率	15.77%	30.30%
	年化收益率	3.32%	6.08%
	最大资产回撤(RMB)	96,417.34	54,918.63
	净利润/最大资产回撤	0.49	1.66

表 9. 基于KNN过滤器的策略绩效评估结果（豆粕期货）

期货	回测指标	无过滤	基于KNN的交易系统
豆粕	胜率	35.45%	37.52%
	净利润	-11,264.40	-1,778.50
	收益率	-3.75%	-0.59%
	年化收益率	-0.85%	-0.13%
	最大资产回撤(RMB)	18,636.25	7,778.28
	净利润/最大资产回撤	-0.60	-0.23

基于NB的唐奇安交易系统在黄金期货下的所有经济评价指标的表现都超过了没有过滤器的系统。具体来说，胜率提高了1.57%，净利润从47,323.07元显著地提高到90,898.48元，这意味着该系统在回测期间盈利的概率更高。使用过滤器后，收益率和年化收益率几乎翻了一番。最大资产回撤从96,417.34元下降到54,918.63元，这表明使用过滤器后交易可能产生的最大损失减少了。由于净利润的增加和最大资产回撤的减少，两者之间的比率值也因此有所增加。关于豆粕期货，经KNN分类器过滤后的唐奇安交易系统在所有评价指标

上也有所提高。例如，胜率从原来的35.45%增加到了37.52%。值得关注的是，虽然净利润是负数，这意味着策略会造成亏损。但从减少损失的角度来看，使用KNN过滤器后净亏损至少减少了6倍，这也反映在收益和年化收益指标上。因此，随着净亏损的减少和最大资产回撤的降低，投资的风险也从而变小了。

上述实验的结果可以简单地概括道，基于ML过滤器视为策略提高了中国期货商品市场三个代表性合约的盈利能力并降低了相应的投资风险。图11的资产曲线展示了在2018年1月至2022年6月之间，使用NB过滤器后黄金期货的红色曲线高于蓝色曲线。这说明了基于NB的唐奇安交易策略在这四年半的时间里都取得了良好的收益。在豆粕期货数据的测试中，如图 12所示，价差曲线呈现稳定的上升趋势，红蓝曲线之间的距离从2018年10月开始拉开，这意味着基于过滤器的策略可以使资产处于相对稳定的状态，尽管处在股市波动大且传统技术指标难以获利的时期。

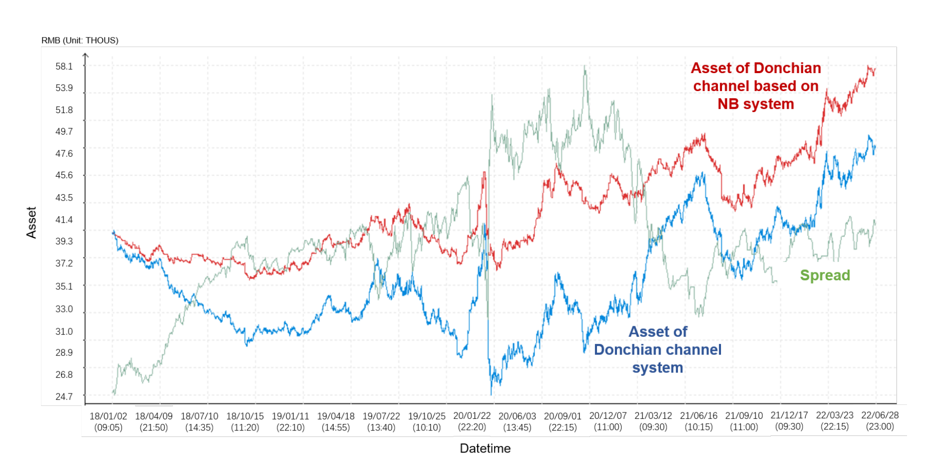


图 11. 基于NB过滤器的唐奇安通道交易系统的资产曲线（黄金期货）

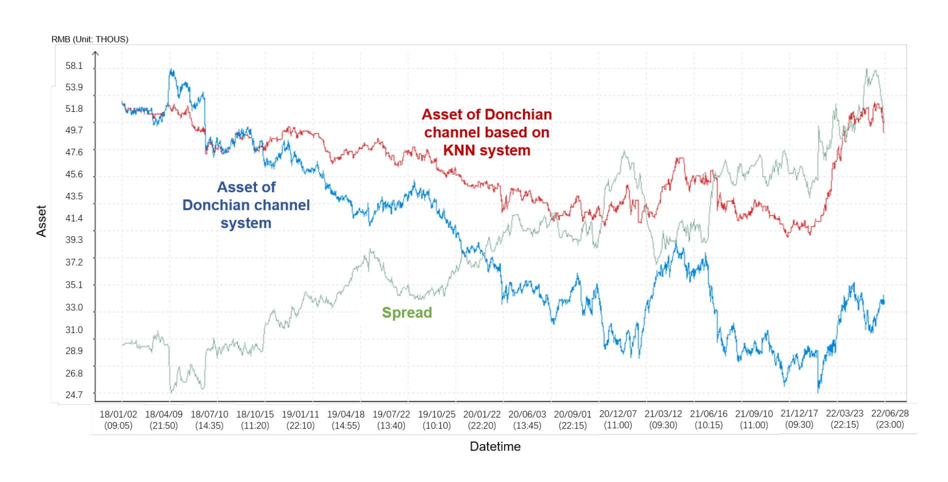


图 12. 基于KNN过滤器的唐奇安通道交易系统的资产曲线（豆粕期货）

6. 结论

通过以上利用机器学习模型结合唐奇安通道交易策略对螺纹钢价格涨跌趋势的预测，得出以下结论：（1）通过对比LR、KNN、NBC、XGBoost、CatBoost和LightGBM分类模型，XGBoost和CatBoost模型，在处理多维度的金融时间序列问题中，XGBoost和CatBoost模型具有较好的预测性能。（2）以上6种分类器，除KNN模型外，均在唐奇安通道交易策略中提高了其胜率和净利润，可作为有效过滤条件使用在趋势跟踪策略中；其中，表现最突出的是 XGBoost 模型，结合其预测能力，抗风险能力，盈利能力和收益稳定性均在本文所有分类器中展现出全方位的优越性，可以认为该分类器使用在唐奇安通道交易策略中作为过滤条件用以预测螺纹钢未来5分钟K线涨跌趋势是最为合适的。此外，通过使用更多的期货数据（黄金期货和豆粕期货）来验证这个基于机器学习的唐奇安交易系统的性能，可以说明使用机器学习技术过滤信号的唐奇安交易策略在某些时间段内是可以提高策略盈利能力和降低投资风险的。综上所述，可供选择的机器学习预测器和技术指标的灵活的组合可以优化传统的量化交易策略。

虽然将机器学习模型引入到交易策略可以有效提绩效表现，但由于特征提取环节中的输入数据的维度较大且其中可能存在很多噪声，这可能会对模型的运行速度产生负面影响。今后可以针对特征选择和降噪处理的方向进行进一步研究。此外，在今后的工作中使用更多的策略，进一步提高机器学习模型与传统策略相结合的可行性。且由于中国的期货市场结构与其他国家或地区不同，未来可以在其他商品期货（如S&P500指数）中测试该系统的性

能。另外，关于深度学习模型的改进，未来的工作中会考虑对LSTM模型的参数进行优化。

参考文献

[1] Gerlein EA, McGinnity M, Belatreche A, Coleman S. Evaluating machine learning classification for financial trading: An empirical approach. Expert Systems with Applications. 2016;54:193-207.

[2] Wu YC, Feng JW. Development and application of artificial neural network. Wireless Personal Communications. 2018;102(2):1645-1656.

[3] Nayyar A, Nguyen GN. Augmenting Dental Care: A Current Perspective. Emerging Technologies for Health and Medicine: Virtual Reality, Augmented Reality, Artificial Intelligence, Internet of Things, Robotics, Industry 4.0. 2018;51.

[4] De Jong K. Evolutionary computation: a unified approach. Proceedings of the Genetic and Evolutionary Computation Conference Companion; 2017 Jul; p.373-388.

[5] Bloch DA. Recipe for quantitative trading with machine learning. Available at SSRN 3232143, 2018.

[6] Zhang J, Wang B. Quantitative Trading Strategies of Shanghai and Shenzhen 300 Index Furtures Based on SVM. Mathematical Theory and Applications. 2017;37(2):112.

[7] Vats P, Samdani K. Study on Machine Learning Techniques In Financial Markets. In: 2019 IEEE International Conference on System, Computation, Automation and Networking (ICSCAN); IEEE; 2019.p.1-5.

[8] Long A, Bi X, Zhang S. An arbitrage strategy model for ferrous metal futures based on LSTM neural network. Journal of University of Science and Technology of China. 2018;48(2):125.

[9] Zheng L, Pan T, Liu J, Ming G, Zhang M, Wang J. Quantitative trading system based on machine learning in Chinese financial market. Journal of Intelligent & Fuzzy Systems. 2020;38(2):1423-1433.

[10] Fisichella M, Garolla F. Can Deep Learning Improve Technical Analysis of Forex Data to Predict Future Price Movements? IEEE Access. 2021;9:153083-153101.

[11] Edwards RD, Magee J, Bassetti WC. Technical analysis of stock trends. CRC press; 2018.

[12] Pring MJ. Technical analysis. International Institute for Technical Research; 1986.

[13] Chen J. Donchian Channels Formula, Calculations, and Uses. Avaliable at: https://www.investopedia.com/terms/d/donchianchannels.asp [Accessed 24th November 2022].

[14] Guides TS. Donchian Trading Strategy–Crawling Along Pattern. Avaliable at: https://tradingstrategyguides.com/donchian-trading-strategy/ [Accessed 24th November 2022].

[15] Swart JN. Testing a price breakout strategy using Donchian Channels. University of Cape Town, 2016.

[16] Si W, Li J, Ding P, Rao R. A multi-objective deep reinforcement learning approach for stock index future’s intraday trading. In: 2017 10th International symposium on computational intelligence and design (ISCID); IEEE; 2017.p.431-436.

[17] Giribone PG, Ligato S, Penone F. Combining robust dynamic neural networks with traditional technical indicators for generating mechanic trading signals. International Journal of Financial Engineering. 2018;5(04):1850037.

[18] Yao Y, Cai S, Wang H. Are technical indicators helpful to investors in china’s stock market? A study based on some distribution forecast models and their combinations. Economic Research-Ekonomska Istraživanja. 2022;35(1):2668-2692.

[19] Bustos O, Pomares-Quimbaya A. Stock market movement forecast: A Systematic review. Expert Systems with Applications. 2020;156:0957-4174.

[20] Han Y, Hu T, Yang J. Are there exploitable trends in commodity futures prices? Journal of Banking & Finance. 2016;70:214-234.

[21] Clare A, Seaton J, Smith PN, Thomas S. Trend following, risk parity and momentum in commodity futures. International Review of Financial Analysis. 2014;31:1-12.

[22] Li B, Zhang D, Zhou Y. Do trend following strategies work in Chinese futures markets? Journal of Futures Markets. 2017;37(12):1226–1254.

[23] Vijh M, Chandola D, Tikkiwal VA, Kumar A. Stock Closing Price Prediction using Machine Learning Techniques. Procedia Computer Science. 2020;167:599-606.

[24] Li L, Wu Y, Ou Y, Li Q, Zhou Y, Chen D. Research on machine learning algorithms and feature extraction for time series. In: 2017 IEEE 28th annual international symposium on personal, indoor, and mobile radio communications (PIMRC); 2017 Oct; IEEE; p. 1-5.

[25] Sang C, Massimo DP. Improving trading technical analysis with TensorFlow Long Short-Term Memory (LSTM) Neural Network. The Journal of Finance and Data Science. 2019;5(1):1-11.

[26] Ayala J, García-Torres M, Noguera JLV, Gómez-Vela F, Divina F. Technical analysis strategy optimization using a machine learning approach in stock market indices. Knowledge-Based Systems. 2021;(): –.

[27] Graves A. Supervised sequence labelling. In: Supervised sequence labelling with recurrent neural networks; 2012; Berlin, Heidelberg: Springer; c2012. p. 5-13.

[28] Hochreiter S, Schmidhuber J. Long short-term memory. Neural computation. 1997;9(8):1735-1780.

[29] Bhandari HN, Rimal B., Pokhrel NR, Rimal R, Dahal KR, Khatri RK. Predicting stock market index using LSTM. Machine Learning with Applications. 2022: 100320.

[30] Chen K, Zhou Y, Dai F. A LSTM-based method for stock returns prediction: A case study of China stock market. Proceedings of the 2015 IEEE international conference on big data (big data); 2015 Oct; Santa Clara, CA; IEEE; p.2823–2824.

[31] Yu Y, Si X, Hu C, Zhang J. A review of recurrent neural networks: LSTM cells and network architectures. Neural computation. 2019;31(7):1235-1270.

[32] Hinton GE, Srivastava N, Krizhevsky A, Sutskever I, Salakhutdinov RR. Improving neural networks by preventing co-adaptation of feature detectors 2012. ArXiv[Preprint]2012.

[33] Fan J, Liu H, Hu Y. Soybean future prices forecasting based on LSTM deep learning. Price Monthly. 2021;2:7-15.

[34] Dvoryatkina S, Golovin D. Neural network technologies for analysis and risk assessment in forecasting the market of industrial financial instruments. Journal of Physics: Conference Series. IOP Publishing; 2022;2176(1):012091.

[35] Fortier M. TA-Lib: Technical analysis library. Available at: www.ta-lib.org [Accessed 28th September 2022].

[36] Guides TS. Monero Trading for Beginners – The world's biggest privacy coin. Available at: tradingstrategyguides.com/monero-trading-for-beginners/ [Accessed 28th September 2022].

[37] Chen S, Ge L. Exploring the attention mechanism in LSTM-based Hong Kong stock price movement prediction. Quantitative Finance. 2019;19(9):1507-1515.

[38] Liu L. Are Bitcon returns predictable?: Evidence from technical indicators. Physica A: Statistical Mechanics and its Applications. 2019;533:121950.

[39] Faijareon C, Sornil O. Evolving and combining technical indicators to generate trading strategies. Physics: Conference Series. 2019;1195(1):012010.